

(12) DEMANDE INTERNATIONALE PUBLIÉE EN VERTU DU TRAITÉ DE COOPÉRATION
EN MATIÈRE DE BREVETS (PCT)

(19) Organisation Mondiale de la Propriété
Intellectuelle
Bureau international



(43) Date de la publication internationale
9 octobre 2003 (09.10.2003)

PCT

(10) Numéro de publication internationale
WO 03/083832 A1

(51) Classification internationale des brevets⁷ :
G10L 15/28, 15/14, 15/18

(21) Numéro de la demande internationale :
PCT/FR03/00884

(22) Date de dépôt international : 20 mars 2003 (20.03.2003)

(25) Langue de dépôt : français

(26) Langue de publication : français

(30) Données relatives à la priorité :
02/04286 29 mars 2002 (29.03.2002) FR

(71) Déposant (pour tous les États désignés sauf US) :
FRANCE TELECOM SA [FR/FR]; 6, place d'Alleray,
F-75015 Paris (FR).

(72) Inventeurs; et
(75) Inventeurs/Déposants (pour US seulement) : **FER-
RIEUX, Alexandre** [FR/FR]; 4, Hent Al Lann, F-22560
Pleumeur Bodou (FR). **DELPHIN-POULAT, Lionel**
[FR/FR]; résidence Kergemar A2, F-22300 Lannion (FR).

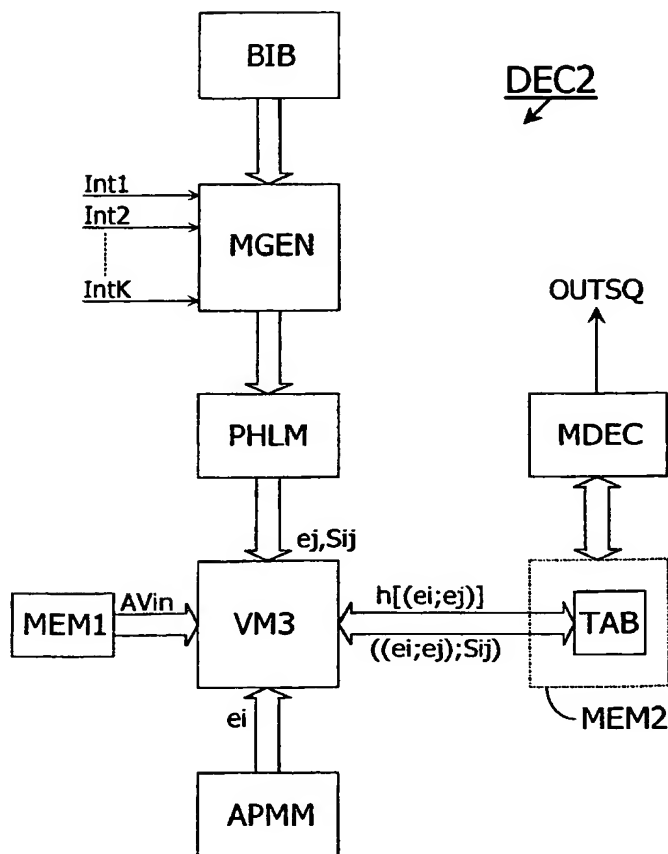
(74) Mandataire : **MAILLET, Alain**; Cabinet Le Guen Mail-
let, 5, place Newquay, B.P. 70250, F-35802 Dinard (FR).

(81) États désignés (national) : AE, AG, AL, AM, AT, AU, AZ,
BA, BB, BG, BR, BY, BZ, CA, CH, CN, CO, CR, CU, CZ,

[Suite sur la page suivante]

(54) Title: SPEECH RECOGNITION METHOD USING A SINGLE TRANSDUCER

(54) Titre : PROCÉDÉ DE RECONNAISSANCE DE PAROLE AU MOYEN D'UN TRANSDUCTEUR UNIQUE



(57) **Abstract:** The invention relates to a method of translating input data AVin into an output lexical sequence OUTSQ. During said method, sub-lexical entities and different possible combinations of said entities are identified as states ei and ej of first and second language models APMM and PHLM respectively. Said combinations are intended to be stored with an associated likelihood value Sij in a table TAB comprising memory areas. Moreover, each of said memory areas is intended to contain at least one combination of states (ei;ej) and is provided with an address equal to a value h[(ei;ej)] of a scalar function h that is applied to parameters specific to the combination (ei; ej). The invention can be used to limit the complexity of accessing information produced by a single transducer which is formed by a single Viterbi VM3 machine operating models APMM and PHLM.

(57) **Abrégé :** La présente invention concerne un procédé de traduction de données d'entrée AVin en une séquence lexicale de sortie OUTSQ, au cours duquel des entités souslexicales et diverses combinaisons possibles desdites entités sont identifiées en tant qu'états ei et ej de premier et deuxième modèles de langage APMM et PHLM, respectivement, destinés à être mémorisés, avec une valeur de vraisemblance Sij associée, dans une table TAB munie de zones mémoire dont chacune est destinée à contenir au moins une combinaison d'états (ei;ej) et est munie d'une adresse égale à une valeur h[(ei;ej)] d'une fonction scalaire h appliquée à des paramètres propres à la combinaison (ei;ej). L'invention permet de limiter la complexité

[Suite sur la page suivante]

WO 03/083832 A1



DE, DK, DM, DZ, EC, EE, ES, FI, GB, GD, GE, GH, GM, HR, HU, ID, IL, IN, IS, JP, KE, KG, KP, KR, KZ, LC, LK, LR, LS, LT, LU, LV, MA, MD, MG, MK, MN, MW, MX, MZ, NO, NZ, OM, PH, PL, PT, RO, RU, SC, SD, SE, SG, SK, SL, TJ, TM, TN, TR, TT, TZ, UA, UG, US, UZ, VC, VN, YU, ZA, ZM, ZW.

FR, GB, GR, HU, IE, IT, LU, MC, NL, PT, RO, SE, SI, SK, TR), brevet OAPI (BF, BJ, CF, CG, CI, CM, GA, GN, GQ, GW, ML, MR, NE, SN, TD, TG).

Publiée :

— avec rapport de recherche internationale

(84) États désignés (régional) : brevet ARIPO (GH, GM, KE, LS, MW, MZ, SD, SL, SZ, TZ, UG, ZM, ZW), brevet eurasien (AM, AZ, BY, KG, KZ, MD, RU, TJ, TM), brevet européen (AT, BE, BG, CH, CY, CZ, DE, DK, EE, ES, FI,

En ce qui concerne les codes à deux lettres et autres abréviations, se référer aux "Notes explicatives relatives aux codes et abréviations" figurant au début de chaque numéro ordinaire de la Gazette du PCT.

Procédé de traduction de données au moyen d'un transducteur unique

La présente invention concerne un procédé de traduction de données d'entrée en au moins une séquence lexicale de sortie, incluant une étape de décodage des données d'entrée au cours de laquelle des entités lexicales dont lesdites données sont représentatives sont identifiées au moyen d'au moins un modèle.

5 De tels procédés sont communément utilisés dans des applications de reconnaissance de parole, où au moins un modèle est mis en œuvre pour reconnaître des informations présentes dans les données d'entrée, une information pouvant être constituée par exemple par un ensemble de vecteurs de paramètres d'un espace acoustique continu, ou encore par un label attribué à une entité sous-lexicale.

10 Dans certaines applications, le qualificatif "lexical" s'appliquera à une phrase considérée dans son ensemble, en tant que suite de mots, et les entités sous-lexicales seront alors des mots, alors que dans d'autres applications, le qualificatif "lexical" s'appliquera à un mot, et les entités sous-lexicales seront alors des phonèmes ou encore des syllabes aptes à former de tels mots, si ceux-ci sont de nature littérale, ou
15 des chiffres, si les mots sont de nature numérique, c'est-à-dire des nombres.

- Une première approche pour opérer une reconnaissance de parole consiste à utiliser un type particulier de modèle qui présente une topologie régulière et est destiné à apprendre toutes les variantes de prononciation de chaque entité lexicale, c'est-à-dire par exemple un mot, inclus dans le modèle. Selon cette première
- 5 approche, les paramètres d'un ensemble de vecteurs acoustiques propre à chaque information qui est présente dans les données d'entrée et correspond à un mot inconnu doivent être comparés à des ensembles de paramètres acoustiques correspondant chacun à l'un des très nombreux symboles contenus dans le modèle, afin d'identifier un symbole modélisé auquel correspond le plus vraisemblablement cette information.
- 10 Une telle approche garantit en théorie un fort taux de reconnaissance si le modèle utilisé est bien conçu, c'est-à-dire quasi-exhaustif, mais une telle quasi-exhaustivité ne peut être obtenue qu'au prix d'un long processus d'apprentissage du modèle, qui doit assimiler une énorme quantité de données représentatives de toutes les variantes de prononciation de chacun des mots inclus dans ce modèle. Cet apprentissage est en
- 15 principe réalisé en faisant prononcer par un grand nombre de personnes tous les mots d'un vocabulaire donné, et à enregistrer toutes les variantes de prononciation de ces mots. Il apparaît clairement que la construction d'un modèle lexical quasi-exhaustif n'est pas envisageable en pratique pour des vocabulaires présentant une taille supérieure à quelques centaines de mots.
- 20 Une deuxième approche a été conçue dans le but de réduire le temps d'apprentissage nécessaire aux applications de reconnaissance de parole, réduction qui est essentielle à des applications de traduction sur de très grands vocabulaires pouvant contenir plusieurs centaines de milliers de mots, laquelle deuxième approche consiste à opérer une décomposition des entités lexicales en les considérant comme des
- 25 assemblages d'entités sous-lexicales, à utiliser un modèle sous-lexical modélisant lesdites entités sous-lexicales en vue de permettre leur identification dans les données d'entrée, et un modèle d'articulation modélisant différentes combinaisons possibles de ces entités sous-lexicales.

- Une telle approche, décrite par exemple au chapitre 16 du manuel "Automatic
- 30 Speech and Speaker Recognition" édité par Kluwer Academic Publishers, permet de

réduire considérablement, par rapport au modèle utilisé dans le cadre de la première approche décrite plus haut, les durées individuelles des processus d'apprentissage du modèle sous-lexical et du modèle d'articulation, car chacun de ces modèles présente une structure simple par rapport au modèle lexical utilisé dans la première approche.

5 Les modes de mise en œuvre connus de cette deuxième approche font le plus souvent appel à un premier et à un deuxième transducteur, chacun formé par un modèle de Markov représentatif d'une certaine source de connaissances, c'est-à-dire, pour reprendre le cas de figure évoqué ci-dessus, un premier modèle de Markov représentatif des entités sous-lexicales et un deuxième modèle de Markov représentatif
10 de combinaisons possibles desdites entités sous-lexicales. Au cours d'une étape de décodage de données d'entrée, des états contenus dans les premier et deuxième transducteurs, lesquels états sont respectivement représentatifs de modélisations possibles des entités sous-lexicales et de modélisations possibles de combinaisons desdites entités sous-lexicales, seront activés. Les états activés des
15 premier et deuxième transducteurs seront alors mémorisés dans des moyens de mémorisation.

Selon une représentation conceptuelle élégante de cette deuxième approche, les premier et deuxième transducteurs peuvent être représentés sous la forme d'un transducteur unique équivalent aux premier et deuxième transducteurs pris dans leur
20 composition, permettant de traduire les données d'entrée en entités lexicales, en exploitant simultanément le modèle sous-lexical et le modèle d'articulation.

Selon cette représentation conceptuelle, la mémorisation des états activés au cours de l'étape de décodage équivaut à une mémorisation d'états de ce transducteur unique, dont chaque état peut être considéré comme un couple formé par un état du
25 premier transducteur formé par le premier modèle construit sur la base d'entités sous-lexicales, d'une part, et par un état du deuxième transducteur formé par le deuxième modèle construit sur la base d'entités lexicales, d'autre part. Une telle mémorisation pourrait être faite de manière anarchique, au fur et à mesure que ces états seront produits. Cependant, le nombre maximum d'états différents que peut prendre le
30 transducteur unique est très grand, car il est égal à un produit entre les nombres

maxima d'états que peuvent prendre chacun des premier et deuxième transducteurs. Par ailleurs, le nombre d'états du transducteur unique effectivement utiles pour le décodage, c'est-à-dire correspondant effectivement à des séquences sous-lexicales et lexicales autorisées dans la langue considérée, est relativement faible par rapport au
5 nombre maximum d'états possibles, particulièrement si des états dont l'activation est peu probable, bien que théoriquement autorisée, sont exclus par convention. Ainsi, une mémorisation anarchique des états produits par le transducteur unique conduit à utiliser une mémoire de taille très importante, dans laquelle les informations représentatives des états produits seront très clairsemées, ce qui conduira à utiliser
10 pour leur adressage à des fins de lecture et/ou d'écriture des nombres de grande taille nécessitant un système de gestion d'accès mémoire indûment complexe par rapport au volume d'informations utiles effectivement contenu dans la mémoire, qui induira des temps d'accès mémoire importants et incompatibles avec des contraintes temporelles propres par exemple à des applications de traduction en temps réel.

15 L'invention a pour but de remédier dans une large mesure à cet inconvénient, en proposant un procédé de traduction de données mettant en œuvre un transducteur unique et des moyens de mémorisation destinés à contenir des informations relatives aux états activés dudit transducteur unique, procédé grâce auquel des accès en lecture/écriture aux dites informations peuvent être exécutés suffisamment rapidement
20 pour autoriser une utilisation dudit procédé dans des applications de traduction en temps réel.

En effet, selon l'invention, un procédé de traduction de données d'entrée en au moins une séquence lexicale de sortie inclut une étape de décodage des données d'entrée au cours de laquelle des entités sous-lexicales dont lesdites données sont
25 représentatives sont identifiées au moyen d'un premier modèle construit sur la base d'entités sous-lexicales prédéterminées, et au cours de laquelle sont générées, au fur et à mesure que les entités sous-lexicales sont identifiées et en référence à au moins un deuxième modèle construit sur la base d'entités lexicales, diverses combinaisons possibles desdites entités sous-lexicales, chaque combinaison étant destinée à être
30 mémorisée, conjointement avec une valeur de vraisemblance associée, dans des

moyens de mémorisation qui incluent une pluralité de zones mémoire dont chacune est apte à contenir au moins l'une desdites combinaisons, chaque zone étant munie d'une adresse égale à une valeur prise par une fonction scalaire prédéterminée lorsque ladite fonction est appliquée à des paramètres propres à des entités sous-lexicales et à leur combinaison destinées à être mémorisées ensemble dans la zone considérée.

L'utilisation de zones mémoire adressées au moyen d'une fonction scalaire prédéterminée permet d'organiser le stockage des informations utiles produites par ce transducteur unique et de simplifier la gestion des accès à ces informations puisque, conformément à l'invention, la mémoire est subdivisée en zones destinées chacune à contenir des informations relatives à des états effectivement produits par le transducteur unique. Ceci autorise un adressage desdites zones au moyen d'un nombre dont la taille est réduite par rapport à la taille nécessaire pour l'adressage d'une mémoire conçue pour mémoriser de manière anarchique n'importe quel couple d'états des premier et deuxième transducteurs.

Dans un mode de mise en œuvre avantageux de l'invention, on choisira pour fonction scalaire prédéterminée une fonction essentiellement injective, c'est-à-dire une fonction, qui, appliquée à différents paramètres prendra sauf exception des valeurs différentes, ce qui permet d'assurer que chaque zone mémoire ne contiendra en principe que des informations relatives à au plus une seule combinaison d'entités sous-lexicales, c'est-à-dire à un seul état du transducteur équivalent, ce qui permet de simplifier encore les accès auxdites informations en supprimant la nécessité d'un tri, au sein d'une même zone mémoire, entre des informations relatives à différentes combinaisons d'entités sous-lexicales.

Dans une variante de ce mode de mise en œuvre, la fonction scalaire prédéterminée sera en outre également essentiellement surjective en plus d'être injective, c'est-à-dire que chaque zone mémoire disponible est destinée à contenir effectivement, sauf exception, des informations relatives à une seule combinaison d'entités sous-lexicales, ce qui représente une utilisation optimale des moyens de mémorisation puisque leur potentiel de mémorisation sera alors pleinement exploité.

Dans cette variante, la fonction scalaire prédéterminée sera en fait essentiellement bijective, en tant qu'à la fois essentiellement injective et surjective.

Les paramètres d'entrée de la fonction scalaire prédéterminée peuvent revêtir de multiples formes selon le mode de mise en œuvre de l'invention choisi. Dans l'un de ces modes de mise en œuvre, le modèle sous-lexical contient des modèles d'entités sous-lexicales dont différents états sont numérotés de façon contiguë et présentent un nombre total inférieur ou égal à un premier nombre prédéterminé propre au modèle sous-lexical, et le modèle d'articulation contient des modèles de combinaisons possibles d'entités sous-lexicales dont différents états sont numérotés de façon contiguë et présentent un nombre total inférieur ou égal à un deuxième nombre prédéterminé propre au modèle d'articulation, les numéros des états des entités sous-lexicales et de leurs combinaisons possibles constituant les paramètres auxquels la fonction scalaire prédéterminée est destinée à être appliquée.

La fonction scalaire prédéterminée peut revêtir de multiples formes selon le mode de mise en œuvre de l'invention choisi. Dans un mode de mise en œuvre particulier de l'invention, chaque valeur prise par la fonction scalaire prédéterminée est une concaténation d'un reste d'une première division entière par le premier nombre prédéterminé du numéro d'un état d'une entité sous-lexicale identifié au moyen du premier modèle et d'un reste d'une deuxième division entière par le deuxième nombre prédéterminé du numéro d'un état d'une combinaison identifié au moyen du deuxième modèle.

Une telle concaténation garantit en principe que les valeurs des restes des première et deuxième divisions entières seront utilisées sans altération aux fins de l'adressage des zones mémoire, entraînant ainsi une réduction maximale d'un risque d'erreur dans l'adressage.

Dans un mode de réalisation particulièrement avantageux de l'invention, en ce qu'il utilise des moyens éprouvés et individuellement connus de l'homme du métier, l'étape de décodage met en œuvre un algorithme de Viterbi appliqué conjointement à un premier modèle de Markov présentant des états représentatifs de différentes modélisations possibles de chaque entité sous-lexicale autorisée dans une langue de

traduction donnée, et à un deuxième modèle de Markov présentant des états représentatifs de différentes modélisations possibles de chaque articulation entre deux entités sous-lexicales autorisée dans ladite langue de traduction.

Sous un aspect général, l'invention concerne également un procédé de
5 traduction de données d'entrée en une séquence lexicale de sortie, incluant une étape de décodage des données d'entrée destinée à être exécutée au moyen d'un algorithme du type algorithme de Viterbi, exploitant simultanément une pluralité de sources de connaissances distinctes formant un transducteur unique dont des états sont destinés à être mémorisés, conjointement avec une valeur de vraisemblance associée, dans des
10 moyens de mémorisation qui incluent une pluralité de zones mémoire dont chacune est apte à contenir au moins l'un desdits états, chaque zone étant munie d'une adresse égale à une valeur prise par une fonction scalaire prédéterminée lorsque ladite fonction est appliquée à des paramètres ~~pour les~~ états dudit transducteur unique.

L'invention concerne également un système de reconnaissance de signaux
15 acoustiques mettant en œuvre un procédé tel que décrit ci-dessus.

Les caractéristiques de l'invention mentionnées ci-dessus, ainsi que d'autres, apparaîtront plus clairement à la lecture de la description suivante d'un exemple de réalisation, ladite description étant faite en relation avec les dessins joints, parmi lesquels :

20 La Fig.1 est un schéma conceptuel décrivant un décodeur dans lequel un procédé conforme à l'invention est mis en œuvre,

La Fig.2 est un schéma décrivant l'organisation d'une table destinée à mémoriser des informations produites par un tel décodeur,

25 La Fig.3 est un schéma fonctionnel décrivant un système de reconnaissance acoustique conforme à un mode de mise en œuvre particulier de l'invention,

La Fig.4 est un schéma fonctionnel décrivant un premier décodeur destiné à exécuter au sein de ce système une première étape de décodage, et

La Fig.5 est un schéma fonctionnel décrivant un deuxième décodeur destiné à exécuter au sein de ce système une deuxième étape de décodage conforme au procédé
30 selon l'invention.

La Fig.1 représente un décodeur DEC destiné à recevoir des données d'entrée AVin et à délivrer une séquence lexicale de sortie LSQ. Ce décodeur DEC inclut une machine de Viterbi VM, destinée à exécuter un algorithme de Viterbi connu de l'homme du métier, laquelle machine de Viterbi VM utilise conjointement un premier
5 modèle de Markov APHM représentatif de toutes les modélisations possibles de chaque entité sous-lexicale autorisée dans une langue de traduction donnée, et un deuxième modèle de Markov PHLM représentatif de toutes les modélisations possibles de chaque articulation entre deux entités sous-lexicales autorisée dans ladite langue de traduction, lesquels premier et deuxième modèles de Markov APHM et
10 PHLM peuvent respectivement être représentés sous la forme d'un premier transducteur T1 destiné à convertir des séquences de vecteurs acoustiques en séquences d'entités sous-lexicales Phsq, par exemple des phonèmes, et sous la forme d'un deuxième transducteur T2 destiné à convertir ces séquences d'entités sous-lexicales Phsq en séquences lexicales LSQ, c'est-à-dire dans cet exemple en
15 séquences de mots. Chaque transducteur T1 ou T2 peut être assimilé à un automate enrichi à états finis, chaque état e_i ou e_j correspondant respectivement à un état d'une entité sous-lexicale ou à un état d'une combinaison de telles entités identifiés par le premier ou deuxième transducteur T1 ou T2. Dans une telle représentation conceptuelle, le décodeur DEC est donc un transducteur unique, équivalent à une
20 composition des premier et deuxième transducteurs T1 et T2, qui exploite simultanément le modèle sous-lexical et le modèle d'articulation et produit des états $(e_i; e_j)$ dont chacun est un couple formé par un état e_i du premier transducteur T1, d'une part, et par un état e_j du deuxième transducteur T2, d'autre part, un état $(e_i; e_j)$ étant par lui-même représentatif d'une combinaison possible d'entités sous-lexicales.
25 Conformément à l'invention, chaque état $(e_i; e_j)$ est destiné à être mémorisé, conjointement avec une valeur de vraisemblance S_{ij} associée, dans des moyens de mémorisation, constitués dans cet exemple par une table TAB.

La Fig.2 représente schématiquement une table TAB, qui inclut une pluralité de zones mémoire MZ1, MZ2, MZ3...MZN, dont chacune est apte à contenir au moins
30 l'un desdits états $(e_{i1}; e_{2j})$ du transducteur unique, accompagné de la valeur de

vraisemblance S_{ij} qui lui a été attribuée. Chaque zone $MZ_1, MZ_2, MZ_3 \dots MZ_N$ est munie d'une adresse égale à une valeur prise par une fonction scalaire h prédéterminée lorsque ladite fonction est appliquée à des paramètres propres à des entités sous-lexicales et à leur combinaison destinée à être mémorisée dans la zone considérée.

Dans le mode de mise en œuvre de l'invention décrit ici, la fonction scalaire h est une fonction essentiellement injective, c'est-à-dire une fonction qui, appliquée à différents paramètres prendra sauf exception des valeurs différentes, ce qui permet d'assurer que chaque zone mémoire MZ_m (pour $m=1$ à N) ne contiendra en principe que des informations relatives à au plus une seule combinaison d'entités sous-lexicales, c'est-à-dire à un seul état $(e_i; e_j)$ du transducteur formé par le décodeur décrit ci-dessus. La fonction scalaire h est en outre également essentiellement surjective dans cet exemple, c'est-à-dire que chaque zone mémoire MZ_m (pour $m=1$ à N) est destinée à contenir effectivement, sauf exception, des informations relatives à un état $(e_i; e_j)$ dudit transducteur. La fonction scalaire h est donc ici essentiellement bijective, en tant qu'à la fois essentiellement injective et essentiellement surjective. Lorsque le transducteur produira un nouvel état $(e_x; e_y)$, il suffira, pour savoir si cette composition d'états des premier et deuxième transducteurs a déjà été produite, et avec quelle vraisemblance, d'interroger la table TAB au moyen de l'adresse $h[(e_x; e_y)]$. Si cette adresse correspond à une zone mémoire MZ_m déjà définie dans la table pour un état $(e_i; e_j)$, une identité entre le nouvel état $(e_x; e_y)$ et l'état $(e_i; e_j)$ déjà mémorisé sera établie.

Dans ce mode de mise en œuvre, le modèle sous-lexical contient différentes modélisations possibles e_i de chaque entité sous-lexicale, numérotées de façon contiguë et présentant un nombre total inférieur ou égal à un premier nombre prédéterminé V_1 propre au modèle sous-lexical, et le modèle d'articulation contient différentes modélisations possibles e_j de possibles combinaisons de ces entités sous-lexicales, numérotées de façon contiguë et présentant un nombre total inférieur ou égal à un deuxième nombre prédéterminé V_2 propre au modèle d'articulation, les

numéros des entités sous-lexicales et de leurs combinaisons possibles constituant les paramètres auxquels la fonction scalaire h prédéterminée est destinée à être appliquée.

Chaque valeur prise par la fonction scalaire prédéterminée est une concaténation d'un reste, qui peut varier de 0 à $(V1-1)$, d'une première division entière par le premier nombre prédéterminé $V1$ du numéro de la modélisation d'un état d'une entité sous-lexicale identifié au moyen du premier modèle et d'un reste, qui peut varier de 0 à $(V2-1)$, d'une deuxième division entière par le deuxième nombre prédéterminé $V2$ du numéro de la modélisation d'un état d'une combinaison d'entités sous-lexicales identifié au moyen du deuxième modèle. Ainsi, si dans un exemple irréaliste car simplifié à l'extrême pour permettre une compréhension aisée de l'invention, les entités sous-lexicales modélisées dans le premier modèle de Markov sont trois phonèmes "p", "a" et "o", dont chacun peut être modélisé par cinq états distincts, c'est-à-dire des états ($ei=0, 1, 2, 3$ ou 4) pour le phonème "p", des états ($ei=5, 6, 7, 8$ ou 9) pour le phonème "a", et des états ($ei=10, 11, 12, 13$ ou 14) pour le phonème "o", le premier nombre prédéterminé $V1$ sera égal à 5.

Si les combinaisons d'entités sous-lexicales modélisées dans le deuxième modèle de Markov sont deux combinaisons "pa" et "po", dont chacune peut être modélisée par deux états distincts, c'est-à-dire des états ($ej=0$ ou 1) pour la combinaison "pa", et des états ($ej=2$ ou 3) pour la combinaison "po", le deuxième nombre prédéterminé sera égal à 4.

Les différentes modélisations possibles des entités sous-lexicales et de leurs combinaisons sont au maximum au nombre de $N=20$, l'adresse $h[(0;0)]$ de la première zone mémoire MZ1 aura pour valeur la concaténation du reste de la division entière $0/V1=0$ avec le reste de la division entière $0/V2=0$ soit la concaténation 00 d'une valeur 0 avec une valeur 0. L'adresse $h[(14;3)]$ de la Nème zone mémoire MZN aura pour valeur la concaténation du reste de la division entière de 14 par $V1$ (avec $V1=5$) avec le reste de la division entière de 3 par $V2$ (avec $V2=4$), soit la concaténation 43 d'une valeur 4 avec une valeur 3.

Une telle concaténation garantit en principe que les valeurs des restes des première et deuxième divisions entières seront utilisées sans altération aux fins de

l'adressage des zones mémoire, entraînant ainsi une réduction maximale d'un risque d'erreur dans l'adressage. Cependant, une telle concaténation conduit à utiliser des nombres rendus artificiellement plus grands que nécessaire par rapport au nombre de zones mémoire N effectivement adressées. Des techniques, connues de l'homme du
5 métier, permettent de comprimer des nombres à concaténer en limitant les pertes d'information liées à une telle compression. On pourra par exemple prévoir de faire se chevaucher des représentations binaires desdits nombres, en réalisant une opération OU-EXCLUSIF entre des bits de poids faible de l'un de ces nombres binaires avec les bits de poids fort de l'autre nombre binaire.

10 Afin de faciliter sa compréhension, la description de l'invention qui précède a été faite dans un exemple d'application où une machine de Viterbi opère sur un transducteur unique formé par une composition de deux modèles de Markov. Cette description est généralisable à des applications où une unique machine de Viterbi exploite simultanément un nombre P supérieur à 2 de sources de connaissances
15 différentes, formant ainsi un transducteur unique destiné à produire des états $(e1i; e2j; \dots; ePs)$, chacun desquels pouvant être mémorisé dans une zone mémoire d'une table, laquelle zone mémoire sera identifiée au moyen d'une adresse $h[(e1i; e2j; \dots; ePs)]$ ou h est une fonction scalaire prédéterminée telle que décrite plus haut.

20 La Fig.3 représente schématiquement un système SYST de reconnaissance acoustique selon un mode de mise en œuvre particulier de l'invention, destiné à traduire un signal acoustique d'entrée ASin en une séquence lexicale de sortie OUTSQ. Dans cet exemple, le signal d'entrée ASin est constitué par un signal électronique analogique, qui pourra provenir par exemple d'un microphone non
25 représenté sur la figure. Dans le mode de réalisation décrit ici, le système SYST inclut un étage d'entrée FE, contenant un dispositif de conversion analogique/numérique ADC, destiné à fournir un signal numérique ASin(1:n), formé d'échantillons ASin(1), ASin(2)...ASin(n) codés chacun sur b bits, et représentatif du signal acoustique d'entrée ASin, et un module d'échantillonnage SA, destiné à convertir le signal
30 acoustique numérisé ASin(1:n) en une séquence de vecteurs acoustiques AVin,

chaque vecteur étant muni de composantes $AV_1, AV_2 \dots AV_r$ où r est la dimension d'un espace acoustique défini pour une application donnée à laquelle le système de traduction SYST est destiné, chacune des composantes AV_i (pour $i=1$ à r) étant évaluée en fonction de caractéristiques propres à cet espace acoustique. Dans d'autres modes de mise en œuvre de l'invention, le signal d'entrée $ASin$ pourra, dès l'origine, être de nature numérique, ce qui permettra de s'affranchir de la présence du dispositif de conversion analogique/numérique ADC au sein de l'étage d'entrée FE.

Le système SYST inclut en outre un premier décodeur DEC1, destiné à fournir une sélection $Int_1, Int_2 \dots Int_K$ d'interprétations possibles de la séquence de vecteurs acoustiques $AVin$ en référence à un modèle APHM construit sur la base d'entités sous-lexicales prédéterminées.

Le système SYST inclut de plus un deuxième décodeur DEC2 dans lequel un procédé de traduction est mis en œuvre en vue d'analyser des données d'entrée constituées par les vecteurs acoustiques $AVin$ en référence à un premier modèle construit sur la base d'entités sous-lexicales prédéterminées, par exemple extrait du modèle APHM, et en référence à un deuxième modèle construit sur la base de modélisations acoustiques provenant d'une bibliothèque BIB. Le deuxième décodeur DEC2 identifiera ainsi celle desdites interprétations $Int_1, Int_2 \dots Int_K$ qui devra constituer la séquence lexicale de sortie OUTSQ.

La fig.4 représente plus en détail le premier décodeur DEC1, qui inclut une première machine de Viterbi VM1, destinée à exécuter une première sous-étape de décodage de la séquence de vecteurs acoustiques $AVin$ représentative du signal acoustique d'entrée et préalablement générée par l'étage d'entrée FE, laquelle séquence sera en outre avantageusement mémorisée dans une unité de stockage MEM1 pour des raisons qui apparaîtront dans la suite de l'exposé. La première sous-étape de décodage est opérée en référence à un modèle de Markov APM autorisant en boucle toutes les entités sous-lexicales, de préférence tous les phonèmes de la langue dans laquelle le signal acoustique d'entrée doit être traduit si l'on considère que les entités lexicales sont des mots, les entités sous-lexicales étant représentées sous forme de vecteurs acoustiques prédéterminés.

La première machine de Viterbi VM1 est apte à restituer une séquence de phonèmes Phsq qui constitue la plus proche traduction phonétique de la séquence de vecteurs acoustiques AVin. Les traitements ultérieurs réalisés par le premier décodeur DEC1 se feront ainsi au niveau phonétique, et non plus au niveau vectoriel, ce qui réduit considérablement la complexité desdits traitements, chaque vecteur étant une entité multidimensionnelle présentant r composantes, tandis qu'un phonème peut en principe être identifié par un label unidimensionnel qui lui est propre, comme par exemple un label "OU" attribué à une voyelle orale "u", ou un label "CH" attribué à une consonne fricative non-voisée "j". La séquence de phonèmes Phsq générée par la première machine de Viterbi VM1 est ainsi constituée d'une succession de labels plus aisément manipulables que ne le seraient des vecteurs acoustiques.

Le premier décodeur DEC1 inclut une deuxième machine de Viterbi VM2 destinée à exécuter une deuxième sous-étape de décodage de la séquence de phonèmes Phsq générée par la première machine de Viterbi VM1. Cette deuxième étape de décodage est opérée en référence à un modèle de Markov PLMM constitué de transcriptions sous-lexicales d'entités lexicales, c'est-à-dire dans cet exemple de transcriptions phonétiques de mots présents dans le vocabulaire de la langue dans laquelle le signal acoustique d'entrée doit être traduit. La deuxième machine de Viterbi est destinée à interpréter la séquence de phonèmes Phsq, qui est fortement bruitée du fait que le modèle APMU utilisé par la première machine de Viterbi VM1 est d'une grande simplicité, et met en œuvre des prédictions et des comparaisons entre des suites de labels de phonèmes contenus dans la séquence de phonèmes Phsq et diverses combinaisons possibles de labels de phonèmes prévues dans le modèle de Markov PLMM. Bien qu'une machine de Viterbi ne restitue usuellement que celle des séquences qui présente la plus grande probabilité, la deuxième machine de Viterbi VM2 mise en œuvre ici restituera avantageusement toutes les séquences de phonèmes $lsq_1, lsq_2 \dots lsq_N$ que ladite deuxième machine VM2 aura pu reconstituer, avec des valeurs de probabilité associées $p_1, p_2 \dots p_N$ qui auront été calculées pour lesdites séquences et seront représentatives de la fiabilité des interprétations du signal acoustique que ces séquences représentent.

Toutes les interprétations possibles $lsq1, lsq2...lsqN$ étant rendues automatiquement disponibles à l'issue de la deuxième sous-étape de décodage, une sélection opérée par un module de sélection SM des K interprétations $Int1, Int2...IntK$ qui présentent les plus fortes valeurs de probabilité est aisée quelle que soit la valeur de K qui aura été choisie.

Les modèles de Markov APM et PLMM peuvent être considérés comme des sous-ensembles du modèle APMM évoqué plus haut.

Les première et deuxième machines de Viterbi VM1 et VM2 peuvent fonctionner en parallèle, la première machine de Viterbi VM1 générant alors au fur et à mesure des labels de phonèmes qui seront immédiatement pris en compte par la deuxième machine de Viterbi VM2, ce qui permet de réduire le délai total perçu par un utilisateur du système nécessaire à la combinaison des première et deuxième sous-étapes de décodage en autorisant la mise en œuvre de l'ensemble des calculs nécessaires au fonctionnement du premier décodeur DEC1 dès que les vecteurs acoustiques AVin représentatifs du signal acoustique d'entrée apparaissent, et ce sans attendre qu'ils aient été entièrement traduits en une séquence complète de phonèmes Phsq par la première machine de Viterbi VM1.

La Fig.5 représente plus en détail un deuxième décodeur DEC2 conforme à un mode de réalisation particulier de l'invention. Ce deuxième décodeur DEC2 inclut une troisième machine de Viterbi VM3 destinée à analyser la séquence de vecteurs acoustiques AVin représentative du signal acoustique d'entrée qui a été préalablement mémorisée à cet effet dans l'unité de stockage MEM1.

A cet effet, la troisième machine de Viterbi VM3 est destinée à identifier les entités sous-lexicales dont les vecteurs acoustiques AVin sont représentatifs au moyen d'un premier modèle construit sur la base d'entités sous-lexicales prédéterminées, dans cet exemple le modèle de Markov APM mis en œuvre dans le premier décodeur et déjà décrit plus haut, et à produire des états e_i représentatifs des entités sous-lexicales ainsi identifiées. Une telle exploitation du modèle de Markov APM peut être représentée comme une mise en œuvre d'un premier transducteur T1 semblable à celui décrit plus haut.

La troisième machine de Viterbi VM3 génère en outre, au fur et à mesure que des entités sous-lexicales sont identifiées et en référence à au moins un modèle de Markov spécifique PHLM construit sur la base d'entités lexicales, diverses combinaisons possibles des entités sous-lexicales, et à produire des états e_2j 5 représentatifs des combinaisons entités sous-lexicales ainsi générées, la combinaison la plus vraisemblable étant destinée à former la séquence lexicale de sortie OUTSQ. Une telle exploitation du modèle de Markov PHLM peut être représentée comme une mise en œuvre d'un deuxième transducteur T2 semblable à celui décrit plus haut.

L'exploitation simultanée des modèles de Markov APMM et PHLM par la 10 troisième machine de Viterbi VM3 peut donc être appréhendée comme l'utilisation d'un transducteur unique formé par une composition des premier et deuxième transducteurs tels ceux décrits plus haut, destiné à produire des états $(e_i; e_j)$ munis chacun d'une valeur de vraisemblance S_{ij} . ~~En conséquence~~ à la description de l'invention qui précède, ces états seront mémorisés dans une table TAB incluse dans 15 une unité de stockage MEM2, qui pourra former partie d'une mémoire centrale ou d'une mémoire cache incluant également l'unité de stockage MEM1, chaque état $(e_i; e_j)$ étant stocké avec sa valeur de vraisemblance associée S_{ij} dans une zone mémoire ayant pour adresse une valeur $h[(e_i; e_j)]$, avec les avantages en termes de rapidité d'accès précédemment évoqués. Un décodeur de mémoire MDEC 20 sélectionnera à l'issue du processus de décodage celle des combinaisons d'entités sous-lexicales mémorisées dans la table TAB qui présentera la plus grande vraisemblance, c'est-à-dire la plus grande valeur de S_{ij} , destinée à former la séquence lexicale de sortie OUTSQ.

Le modèle de Markov spécifique PHLM est ici spécialement généré par un 25 module de création de modèle MGEN, et est uniquement représentatif d'assemblages possibles de phonèmes au sein des séquences de mots formées par les diverses interprétations phonétiques $Int_1, Int_2, \dots, Int_K$ du signal acoustique d'entrée délivrées par le premier décodeur, lesquels assemblages sont représentés par des modélisations acoustiques provenant d'une bibliothèque BIB des entités lexicales qui correspondent

à ces interprétations. Le modèle de Markov spécifique PHLM présente donc une taille restreinte du fait de sa spécificité.

De la sorte, les accès aux unités de stockage MEM1 et MEM2, ainsi qu'au différents modèles de Markov utilisés dans l'exemple de mise en œuvre de l'invention décrit ci-dessus nécessitent une gestion peu complexe, du fait de la simplicité de structure desdits modèles et du système d'adressage des informations destinées à être mémorisées et lues dans lesdites unités de stockage. Ces accès mémoire peuvent donc être exécutés suffisamment rapidement pour rendre le système décrit dans cet exemple apte à accomplir des traductions en temps réel de données d'entrée en séquences lexicales de sortie.

Bien que l'invention ait été décrite ici dans le cadre d'une application au sein d'un système incluant deux décodeurs disposés en cascade, il est tout-à-fait envisageable, dans l'exemple de mise en œuvre de l'invention, de n'utiliser qu'un unique décodeur semblable au deuxième décodeur décrit plus haut, qui pourra par exemple opérer une analyse acoustico-phonétique et mémoriser, au fur et à mesure que des phonèmes seront identifiés, diverses combinaisons possibles desdits phonèmes, la combinaison de phonèmes la plus vraisemblable étant destinée à former la séquence lexicale de sortie.

REVENDECATIONS

- 1) Procédé de traduction de données d'entrée en au moins une séquence lexicale de sortie, incluant une étape de décodage des données d'entrée au cours de laquelle des entités sous-lexicales dont lesdites données sont représentatives sont identifiées au moyen d'un premier modèle construit sur la base d'entités sous-lexicales
5 prédéterminées, et au cours de laquelle sont générées, au fur et à mesure que les entités sous-lexicales sont identifiées et en référence à au moins un deuxième modèle construit sur la base d'entités lexicales, diverses combinaisons possibles desdites entités sous-lexicales, chaque combinaison étant destinée à être mémorisée, conjointement avec une valeur de vraisemblance associée, dans des moyens de
10 mémorisation qui incluent une pluralité de zones mémoire dont chacune est apte à contenir au moins l'une desdites combinaisons, chaque zone étant munie d'une adresse égale à une valeur prise par une fonction scalaire prédéterminée lorsque ladite fonction est appliquée à des paramètres propres à des entités sous-lexicales et à leur combinaison destinées à être mémorisées ensemble dans la zone considérée.
- 15 2) Procédé de traduction selon la revendication 1, dans lequel la fonction scalaire prédéterminée est une fonction essentiellement injective.
- 3) Procédé de traduction selon la revendication 2, dans lequel la fonction scalaire prédéterminée est en outre également essentiellement surjective.
- 4) Procédé de traduction selon la revendication 1, dans lequel le modèle sous-
20 lexical contient des modèles d'entités sous-lexicales dont différents états sont numérotés de façon contiguë et présentent un nombre total inférieur ou égal à un premier nombre prédéterminé propre au modèle sous-lexical, et dans lequel le modèle d'articulation contient des modèles de combinaisons possibles d'entités sous-lexicales dont différents états sont numérotés de façon contiguë et présentent un nombre total
25 inférieur ou égal à un deuxième nombre prédéterminé propre au modèle d'articulation, les numéros des états des entités sous-lexicales et de leurs combinaisons possibles constituant les paramètres auxquels la fonction scalaire prédéterminée est destinée à être appliquée.

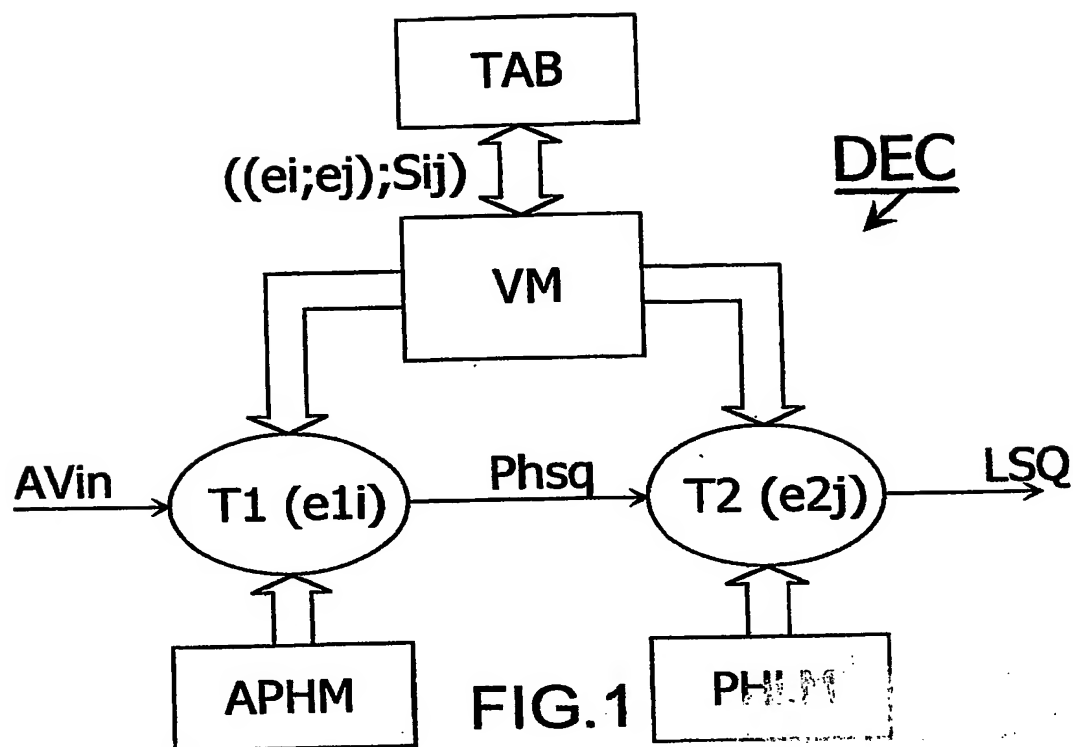
5) Procédé de traduction selon la revendication 4, dans lequel chaque valeur prise par la fonction scalaire prédéterminée est une concaténation d'un reste d'une première division entière par le premier nombre prédéterminé du numéro d'un état d'une entité sous-lexicale identifié au moyen du premier modèle et d'un reste d'une deuxième division entière par le deuxième nombre prédéterminé du numéro d'un état d'une combinaison identifié au moyen du deuxième modèle.

6) Procédé de traduction selon l'une des revendications 1 à 5, selon lequel l'étape de décodage met en œuvre un algorithme de Viterbi appliqué conjointement à un premier modèle de Markov présentant des états représentatifs de différentes modélisations possibles de chaque entité sous-lexicale autorisée dans une langue de traduction donnée, et à un deuxième modèle de Markov présentant des états représentatifs de différentes modélisations possibles de chaque articulation entre deux entités sous-lexicales autorisée dans ladite langue de traduction.

7) Procédé de traduction de données d'entrée en une séquence lexicale de sortie, incluant une étape de décodage des données d'entrée destinée à être exécutée au moyen d'un algorithme du type algorithme de Viterbi, exploitant simultanément une pluralité de sources de connaissances distinctes formant un transducteur unique dont des états sont destinés à être mémorisés, conjointement avec une valeur de vraisemblance associée, dans des moyens de mémorisation qui incluent une pluralité de zones mémoire dont chacune est apte à contenir au moins l'un desdits états, chaque zone étant munie d'une adresse égale à une valeur prise par une fonction scalaire prédéterminée lorsque ladite fonction est appliquée à des paramètres propres aux états dudit transducteur unique.

8) Système de reconnaissance vocale mettant en œuvre un procédé de traduction conforme à l'une des revendications 1 à 7.

1/4




TAB

$h[(e_i; e_j)]$	$((e_i; e_j); S_{ij})$	
00	$((0; 0); S_{00})$	MZ1
10	$((1; 0); S_{10})$	MZ2
20	$((2; 0); S_{20})$	MZ3
⋮	⋮	
43	$((4; 3); S_{43})$	MZN

FIG.2

2/4



3/4




FIG. 4

4/4

